



Catarina Alexandra Couteiro Martins

Licenciada em Engenharia Eletrotécnica e de Computadores

Aplicação de Modelos Estatísticos à Previsão de Produção de Energia Elétrica

Dissertação para obtenção do Grau de Mestre em
Engenharia Eletrotécnica e de Computadores

Orientador: Professor Doutor Pedro Miguel Ribeiro Pereira, Professor
Auxiliar, FCT-UNL

Júri

Presidente: Professor Doutor Luís Filipe dos Santos Gomes, FCT-UNL
Arguente: Professor Doutor Luís Filipe Figueira de Brito Palma, FCT-UNL
Vogal: Professor Doutor Pedro Miguel Ribeiro Pereira, FCT-UNL



FACULDADE DE
CIÊNCIAS E TECNOLOGIA
UNIVERSIDADE NOVA DE LISBOA

Setembro, 2019

Aplicação de Modelos Estatísticos à Previsão de Produção de Energia Elétrica

Copyright © Catarina Alexandra Couteiro Martins, Faculdade de Ciências e Tecnologia, Universidade NOVA de Lisboa.

A Faculdade de Ciências e Tecnologia e a Universidade NOVA de Lisboa têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objetivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.

*Dedico à minha família e ao meu namorado que me
apoiam ao longo deste percurso.*

AGRADECIMENTOS

Gostaria de agradecer ao meu orientador Professor Pedro Pereira por me ter dado a oportunidade de desenvolver este tema e pelo apoio prestado.

Um grande agradecimento à minha família, especialmente aos meus pais e ao meu irmão pelo apoio que sempre me deram ao longo da minha vida pessoal e académica, principalmente nos momentos mais difíceis.

Aos meus amigos e colegas, nomeadamente à Ana Rita Rogado, Mara Oliveira, Rodrigo Francisco e Rúben Nogueira com quem tive o prazer de partilhar uma das etapas mais importantes na minha vida, agradeço pela amizade sincera e pelo apoio que me deram.

Por último quero agradecer ao meu namorado por me ter acompanhado ao longo destes anos e por me apoiar nos momentos mais difíceis.

A todos os que contribuíram para o meu percurso pessoal e académico e me acompanharam ao longo deste caminho, obrigada!

RESUMO

Com o crescimento populacional e a crescente preocupação com o meio ambiente a aposta na produção de energia elétrica a partir de fontes renováveis foi reforçada. Uma das grandes apostas em Portugal é a energia eólica, que é considerada uma das energias mais limpas, no entanto a sua previsão está associada a alguma incerteza devido à variabilidade do vento. Desta forma foi necessário criar ferramentas de previsão de produção de energia elétrica, por conversão de energia eólica. Vários modelos de previsão têm sido usados, desde modelos de previsão numéricos a modelos estatísticos.

Neste trabalho pretende-se realizar a previsão de produção de energia recorrendo a 2 modelos estatísticos (estimativa por regressão polinomial e estimativa baseada em equações não-polinomiais) para vários horizontes temporais. A escolha recaiu sobre os modelos estatísticos uma vez que são relativamente fáceis de implementar e apenas necessitam de dados recolhidos previamente para o local em estudo.

Os resultados obtidos para os modelos de previsão comparativamente aos resultados reais permitem concluir que estes modelos podem ser utilizados para prever a produção da potência uma vez que apresentaram relativamente bom desempenho.

Palavras-chave: Previsão, Modelos Estatísticos, Energias Renováveis, Energia Elétrica.

ABSTRACT

With the global population growth allied with the current increase with environment concern, the production of energy using renewable sources has been strengthened. One of Portugal's main focus is the wind energy, which is considered a clean energy source, although wind power forecasts are associated with an high uncertainty due to wind's high variability both in speed and direction. Naturally it was necessary to create wind power prediction tools. Several models of prediction have been used, from numerical prediction to statistical models.

In this thesis it is intended to calculate wind power prediction based on two statistical models (estimation using polynomial regression and estimation based on non-polynomial equations) for several time horizons. The statistical models were chosen because they are relatively easy to implement and only need previously gathered data from the place of study.

The results of both models compared to real data affirms that these models can be used to predict wind power as both of them performed relatively well.

Keywords: Wind Power Prediction, Statistical Models, Renewable Energies, Electric Energy.

ÍNDICE

Lista de Figuras	xv
Lista de Tabelas	xvii
Siglas	xix
1 Introdução	1
1.1 Enquadramento e Motivação	1
1.2 Objetivos	4
1.3 Estrutura	4
2 Estado da Arte	7
2.1 Modelos Preditivos	7
2.1.1 Modelos Físicos	8
2.1.2 Modelos Estatísticos e de Inteligência Artificial	8
2.1.3 Modelos Híbridos	13
2.2 Filtros	14
2.3 Trabalhos Relacionados	16
2.4 Sinopse	19
3 Metodologia	21
3.1 Metodologia Adotada	21
3.2 Recolha de Dados e Seleção das Variáveis de Entrada no Sistema .	23
3.2.1 Recolha de Dados	23
3.2.2 Sinopse	26
3.3 <i>Script Matlab</i>	27
3.3.1 Tratamento dos Dados	28
3.3.2 Seleção do Modelo de Previsão	31
3.3.3 Treino e Validação do Modelo	33
3.3.4 Interface com o Utilizador	34

4	Treino e Validação	37
4.1	Desenvolvimento do Modelo de Regressão Polinomial	37
4.1.1	Horizonte Temporal- 1 mês	37
4.1.2	Horizonte Temporal- 1 semana	41
4.1.3	Horizonte Temporal- 1 dia	41
4.1.4	Horizonte Temporal- 12 Horas	43
4.1.5	Horizonte Temporal- 6 Horas	44
4.2	Desenvolvimento do Modelo de Previsão baseado em Equações Não-Polinomiais	45
4.2.1	Horizonte Temporal- 1 mês	45
4.2.2	Horizonte Temporal- 1 semana	47
4.2.3	Horizonte Temporal- 1 dia	47
4.2.4	Horizonte Temporal- 12 Horas	49
4.2.5	Horizonte Temporal- 6 Horas	50
4.3	Resultados dos Indicadores Estatísticos para os 2 modelos	50
4.4	Interface com o utilizador	52
5	Conclusões e Trabalho Futuro	55
5.1	Conclusões	55
5.2	Trabalho Futuro	56
	Bibliografia	59

LISTA DE FIGURAS

1.1	Mix de Produção Elétrica de Portugal em 2018 (%) [2].	2
1.2	Taxa de Penetração da Eletricidade Renovável no Consumo Elétrico Nacional (2010-2020) [2].	2
2.1	Esquema representativo de um neurónio artificial [11].	11
2.2	(a) Função escalão (b) Função linear por partes [11]	12
2.3	(a) Modelo Tradicional e (b) Modelo <i>Fuzzy</i> representativos da altura [13].	13
2.4	Efeito da constante a no sinal de saída [17].	15
3.1	Arquitetura do sistema.	21
3.2	Metodologia adotada.	22
3.3	Anemómetro <i>Davis Cup</i> instalado na Estação meteorológica.	23
3.4	Gerador Eólico instalado no topo do DEE.	24
3.5	Contador de Energia referente à produção eólica.	25
3.6	Arquitetura geral do Sistema.	26
3.7	Script desenvolvido.	27
3.8	Variação da velocidade do vento ao longo de 1 semana.	28
3.9	Comparação dos dados originais com a redução de amostras.	29
3.10	Comparação dos dados originais com a eliminação de <i>outliers</i>	30
3.11	Aplicação do filtro da média móvel com várias janelas deslizantes. . .	30
3.12	Polinómio calculado para o M1 para um mês do conjunto de treino. .	32
3.13	Polinómio calculado para o M2 para um mês do conjunto de treino. .	33
3.14	Período de Treino e de Validação do Modelo.	34
3.15	Aplicação desenvolvida em <i>Matlab</i>	35
3.16	Simulação para o mês de Setembro com o modelo de Regressão Polinomial.	35
4.1	Velocidade do vento mensal para o mês de Setembro de 2012.	38
4.2	Potência mensal para o mês de Setembro de 2012.	38

4.3	Potência e velocidade do vento mensal para o mês de Setembro de 2012 após o tratamento de dados.	39
4.4	Polinómio obtido após treino do modelo para o mês de Setembro de 2012.	40
4.5	Previsão da potência para o mês de Setembro de 2013.	40
4.6	Previsão da potência para a semana de Setembro de 2013.	41
4.7	Polinómio obtido após o treino do modelo para a semana de Setembro de 2012.	42
4.8	Previsão diária de Setembro de 2013.	42
4.9	Polinómio obtido após o treino do modelo para o dia 1 de Setembro de 2012.	43
4.10	Previsão diária de Setembro de 2013.	44
4.11	Previsão diária de Setembro de 2013.	45
4.12	Polinómio obtido após treino do modelo para o mês de Setembro de 2012.	46
4.13	Previsão da potência para o mês de Setembro de 2013.	46
4.14	Previsão da potência para a semana de Setembro de 2013.	47
4.15	Polinómio obtido após o treino do modelo para a semana de Setembro de 2012.	48
4.16	Previsão diária de Setembro de 2013.	48
4.17	Polinómio obtido após o treino do modelo para o dia 1 de Setembro de 2012.	49
4.18	Previsão diária de Setembro de 2013.	49
4.19	Previsão diária de Setembro de 2013.	50
4.20	Resultados dos Indicadores Estatísticos para os 2 modelos de previsão para vários horizontes temporais.	51
4.21	Produção em função da velocidade do vento.	51
4.22	Resultados obtidos para as 12h do mês de Setembro para o M1.	52
4.23	Resultados obtidos para as 12h do mês de Setembro para o M2.	52

LISTA DE TABELAS

2.1	Quadro resumo dos modelos abordados.	18
3.1	Especificações do Anemómetro.	24
3.2	Especificações do Gerador Eólico FD3.6-2000-10L.	24

SIGLAS

AWPPS	<i>ARMINES Wind Power Prediction System.</i>
BRAMS	<i>Brazilian developments on the Regional Atmospheric Modelling System.</i>
DEEC	Departamento de Engenharia Electrotécnica e de Computadores.
DTU	<i>Technical University of Denmark.</i>
FCT	Faculdade de Ciências e Tecnologia.
HIRLAM	<i>High-Resolution Limited Area Model.</i>
IA	Inteligência Artificial.
MAPE	<i>Mean Absolute Percent Error.</i>
NWP	<i>Numerical Weather Prediction.</i>
PNAEE	Plano Nacional de Ação para a Eficiência Energética.
PNAER	Plano Nacional de Ação para as Energias Renováveis.
RMSE	<i>Root Mean Square Error.</i>
RNA	Redes Neurais Artificiais.
SCADA	<i>Supervisory Control and Data Acquisition.</i>
UNL	Universidade Nova de Lisboa.
WASP	<i>Wind Atlas Application and Analysis.</i>
WPPT	<i>Wind Power Prediction Tool.</i>

INTRODUÇÃO

1.1 Enquadramento e Motivação

Hoje em dia é de extrema importância recorrer às energias renováveis para produção de energia elétrica em detrimento do recurso aos combustíveis fósseis. Existe cada vez mais a preocupação com o meio ambiente e o impacto que a produção de energia a partir dos recursos fósseis acarreta, tendo sido reforçada a aposta nas energias renováveis e, especialmente, na energia eólica em Portugal e também no Mundo [1].

A União Europeia tem vindo, desde 1991, a promover o desenvolvimento das fontes de energia renovável, a diversificação e a segurança das tecnologias de abastecimento, a descentralização da produção, a redução da dependência energética do exterior e a redução de emissões de gases com efeitos de estufa. O governo Português tem seguido esta estratégia e, desde 2013, tem em vigor o Plano Nacional de Ação para as Energias Renováveis (PNAER) e o Plano Nacional de Ação para a Eficiência Energética (PNAEE). Para cumprir as metas da União Europeia, Portugal terá de atingir uma taxa de penetração das renováveis no consumo elétrico de 60% [2].

Em 2018 o peso da eletricidade renovável atingiu o valor de 52,6% em termos relativos face ao total da produção nacional de eletricidade, como é possível observar na Figura 1.1. No período entre Janeiro e Julho de 2019 estima-se que o valor seja de 52,3% [2].




Figura 1.1: Mix de Produção Elétrica de Portugal em 2018 (%) [2].

Apesar do peso da eletricidade renovável, Portugal está cada vez mais distante da meta definida pela União Europeia como é possível observar na Figura 1.2.



Figura 1.2: Taxa de Penetração da Eletricidade Renovável no Consumo Elétrico Nacional (2010-2020) [2].

A energia eólica é considerada uma das fontes de energia mais limpa, e o seu funcionamento tem por base a interação do vento com a turbina eólica, o vento atua nas pás fazendo-as girar e desta forma a energia cinética do vento é convertida em energia mecânica que posteriormente é convertida em energia elétrica.

Com a aposta nas energias renováveis a quota relativamente à energia eólica tem vindo a aumentar, este aumento deve-se essencialmente à disponibilidade do recurso no nosso país e à maturidade da tecnologia. Este aumento da quantidade de energia produzida pela geração eólica tem também associado um aumento da incerteza de produção devido à variabilidade do vento. Surgem assim inúmeros desafios para os intervenientes no mercado de eletricidade devido à dificuldade dos operadores em balancear a procura e a oferta de energia de forma eficiente [3].

Desta forma foi necessário criar uma ferramenta de previsão de energia elétrica, por conversão de energia eólica, que conseguisse estimar a energia elétrica produzida num determinado horizonte temporal para ajudar na gestão de sistemas de produção deste tipo de energia [4]. Esta previsão é necessária uma vez que devido à variabilidade do vento existe alguma incerteza associada à sua previsão, pelo que existem alguns aspetos a considerar como por exemplo [5]:

- **Participação em Mercados de Eletricidade** - Os promotores dos parques eólicos poderão ter que apresentar propostas de produção de hora a hora e com uma antecedência superior a 24 horas, no caso do mercado diário.
- **Segurança de Abastecimento** - Os sistemas de previsão permitem uma maior eficiência no processo de contratação de serviços de reserva uma vez que reduzem a incerteza associada à produção esperada dos parques eólicos. A estimativa da produção eólica é também importante no caso da possibilidade de avarias de unidades produtoras e da variabilidade do vento para definir as reservas adequadas para garantir a qualidade do serviço.
- **Gestão de Centros de Produção** - No processo de despacho das centrais eólicas é necessário considerar, para além das restrições da rede elétrica, as estimativas de produção elétrica e o seu grau de incerteza associado. Estas estimativas são importantes uma vez que quanto maior for a geração eólica, menores serão os custos marginais de produção de energia por meios convencionais.

Todos os participantes na indústria elétrica beneficiam das previsões de produção eólica, pelo que existe um aumento do apoio e esforços no desenvolvimento de sistemas mais precisos e fiáveis de modo a integrar este tipo de energia no sistema [3].

Os sistemas são caracterizados segundo o horizonte temporal para o qual realiza previsões e segundo o tipo de abordagem que utiliza (física, estatística e de

inteligência artificial, ou híbrida). A escolha do modelo mais adequado depende da aplicação à qual este se destina, e por isso varia de caso para caso [3].

Tendo por base os modelos de predição será possível prever a potência elétrica produzida a partir do vento pelo gerador eólico presente no DEEC recorrendo a dados recolhidos previamente sobre a velocidade e direção do vento. No âmbito desta dissertação apenas serão estudados os modelos estatísticos.

1.2 Objetivos

O objetivo principal desta dissertação é a construção de um modelo de previsão da produção de energia elétrica a partir do vento, para isso serão analisados os vários modelos preditivos que se encontram descritos na secção 2.1.2 e será escolhido o mais adequado. Após a seleção do modelo será necessário proceder à sua validação recorrendo a indicadores estatísticos.

Para se conseguir estimar a potência é necessário recorrer a dados obtidos anteriormente referentes à velocidade do vento. Para os dados poderem ser utilizados no modelo de previsão é necessário proceder a um pré-processamento dos dados para eliminar ruído existente recorrendo a filtros, os filtros encontram-se descritos na secção 2.2. Será feito o teste com vários filtros e por último será escolhido o que apresentar um sinal mais suavizado.

Por último temos como objetivo secundário a construção de uma aplicação recorrendo ao *software Matlab* que permite uma simulação em tempo real da previsão da produção de energia eólica dando ao utilizador liberdade para escolher o período da previsão, o tipo de modelo utilizado e o horizonte temporal apresentando por fim um gráfico comparativo da produção real com a prevista e a quantidade de energia produzida estimada.

1.3 Estrutura

A estrutura desta dissertação está dividida em 5 capítulos.

No primeiro capítulo é feita uma introdução ao trabalho, a organização da dissertação e são ainda apresentados os objetivos e motivações.

No segundo capítulo é feita uma abordagem aos modelos de previsão existentes e já implementados. Apresenta uma secção referente a filtragem de dados.

O terceiro capítulo refere-se à metodologia de trabalho adotada começando pela aquisição e tratamento dos dados, seleção do modelo de previsão e da construção da aplicação.

No quarto capítulo é feita a validação da metodologia adotada e são avaliados os resultados obtidos com recurso aos dados reais.

Por último, no quinto capítulo, são feitas as conclusões ao trabalho desenvolvido e sugestão de trabalhos futuros.

ESTADO DA ARTE

Neste capítulo será feita uma abordagem aos modelos de previsão existentes para a produção de potência. Apresenta-se ainda uma secção relativa a filtragem de dados para atenuação do ruído com alguns exemplos. Por fim é feita uma abordagem a modelos já implementados relacionados com a previsão de produção de energia.

2.1 Modelos Preditivos

O uso de metodologias capazes de criar modelos precisos e robustos têm vindo a ser utilizadas em diferentes áreas, tais como a de controlo de sistemas, previsão de indicadores sócio-económicos e na previsão de produção de energia elétrica através de fontes renováveis [6].

Os modelos de previsão para a produção de energia elétrica podem ser classificados da seguinte forma:

- Modelos Físicos;
- Modelos Estatísticos e de Inteligência Artificial;
- Modelos Híbridos;

Os tipos de modelos existentes serão explicados em detalhe ao longo deste capítulo, com maior enfoque nos Modelos Estatísticos.

2.1.1 Modelos Físicos

A predição por modelos físicos baseados em dados meteorológicos obtidos pelo sistema numérico de previsão NWP (velocidade e direção do vento, densidade do ar e pressão, temperatura e humidade), e em informações do ambiente (rugosidade das superfícies e obstáculos) estima os valores ótimos da velocidade do vento, pressão do ar, temperatura e direção do vento. Com base nos resultados estimados é possível prever a potência produzida com base na curva de potência [7].

Os modelos físicos são utilizados para aumentar a resolução do modelo numérico NWP por forma a atingir resultados de predição mais precisos. Estes modelos necessitam de muita capacidade de computação devido ao uso de parametrizações baseadas numa descrição detalhada da atmosfera e por isso são realizados em supercomputadores para obter os melhores resultados para a predição. Dados meteorológicos incorretos produzem erros no sistema que levam a erros cumulativos o que afeta a precisão da previsão [7], [8].

2.1.2 Modelos Estatísticos e de Inteligência Artificial

A previsão da potência tendo por base modelos estatísticos é mais barata de implementar comparativamente aos outros modelos. Os modelos estatísticos são baseados em dados de observação do vento para prever a produção de energia para curtos horizontes temporais. A desvantagem deste método é que à medida que se aumenta o horizonte temporal o erro associado à predição também aumenta, por este motivo estes modelos são usados para curtos horizontes temporais.

Para o caso da predição da produção de energia eólica os dados usados seriam a velocidade do vento, w_{obs} , e a potência eólica, p_{obs} . Um conjunto de dados de longa duração destas variáveis permite descodificar a relação existente entre os dados de entrada e a saída obtida. Desta forma, a produção atual é contabilizada e alguns fatores que interferem com a eficiência do sistema, como por exemplo características do local e interações com outras turbinas existentes no local, que não são tidas em conta pelos fabricantes nos cálculos das curvas características, são consideradas [9].

Recorrendo a métodos estatísticos de regressão linear, uma variedade de modelos é ajustada aos dados existentes inicialmente. De seguida as velocidades do vento obtidas através de modelos NWP, w_{for} , são otimizadas recorrendo a filtros e estes dados são utilizados para estimar a potência de saída da turbina. Os modelos que se baseiam nestas características podem ser inseridos nas seguintes categorias [9]:

- Estimativa por Regressão Polinomial;
- Estimativa baseada na Curva de Potência;
- Estimativa baseada em equações Não-Polinomiais.

Estimativa por Regressão Polinomial

Um dos métodos estatísticos básicos para a previsão da potência é a descrição da potência gerada por uma turbina como uma função cúbica da velocidade do vento. Esta abordagem é equivalente à inicialmente proposta por [10], em que se estima a energia produzida aplicando múltiplos métodos de regressão à velocidade do vento prevista e a potência medida na turbina [9]:

$$p_{t+k} = a_k w_{t+k} + b_k w_{t+k}^2 + c_k w_{t+k}^3 + d_k p_t + l_k + e_{t+k} \quad (2.1)$$

onde p_{t+k} é a potência prevista, w_{t+k} é a velocidade do vento prevista, p_t é a potência obtida na amostra anterior e a, b, c, d, l, e são os pesos correspondentes.

Uma abordagem mais simples corresponde à aplicação da equação (3.2) removendo a amostra anterior da potência [9]:

$$p_{t+k} = a_k w_{t+k} + b_k w_{t+k}^2 + c_k w_{t+k}^3 + l_k + e_{t+k} \quad (2.2)$$

Este esquema pode obter diferentes pesos estatísticos dependendo dos valores da velocidade do vento, uma vez que estas equações do tipo não-linear apresentam um comportamento variável para diferentes valores de entrada [9].

Estimativa baseada na Curva de Potência

A implementação da curva característica que é descrita em baixo é muito utilizada em aplicações de previsão da potência e fornece uma ferramenta segura para converter a velocidade do vento em potência [9].

Cada turbina tem uma curva característica associada que descreve o processo de conversão da energia cinética do vento em potência elétrica que é fornecida pelo fabricante. Para formular a correspondência da velocidade do vento e da potência de saída são tidos em consideração os seguintes aspetos: a correlação entre a velocidade do vento e a potência eólica especificado pelo fabricante e pela equação teórica da potência disponível :

$$P = \frac{1}{2} \rho_{ar} A_r v^3 \quad (2.3)$$

onde v é a velocidade do vento, A_r é a área do rotor exposta ao vento e ρ_{ar} a densidade do ar. Neste estudo os valores da curva característica foram ajustados a uma função polinomial cúbica para evitar discontinuidades [9].

Tendo em conta que a energia produzida depende do desempenho da turbina eólica, foram adotadas duas equações matemáticas. A primeira equação expressa a potência p_{t+k} como uma analogia linear da potência obtida da curva característica $po(w_{t+k})$ [9]:

$$p_{t+k} = a \cdot po(w_{t+k}) + e \quad (2.4)$$

Uma forma relativa da equação (2.4) pode ser obtida adicionando um termo extra que representa a potência providenciada p_{t+k} relacionada com a potência de saída numa amostra anterior [9]:

$$p_{t+k} = a \cdot po(w_{t+k}) + b \cdot p_t + e \quad (2.5)$$

Estimativa baseada em equações Não-Polinomiais

Um problema típico dos modelos anteriores é o controlo da forma não-linear da curva de potência obtida que é muito sensível a variações na velocidade do vento. Uma forma de contornar este problema é proposta em [9], em que se adaptam funções hiperbólicas não-lineares contendo termos trigonométricos que descrevem corretamente comportamentos não-lineares, como a dependência da potência de saída da velocidade do vento. Desta forma a função tangente hiperbólica é usada num modelo da seguinte forma:

$$p_{t+k} = a_0 \cdot \tanh\left(\frac{w_{t+k} - a_1}{a_2}\right) + a_3 \quad (2.6)$$

onde p_{t+k} é a potência de saída, w_{t+k} é a velocidade do vento e a_i são os coeficientes de regressão com significado físico específico que significam: a_0 representa o fator de escala da curva, a_1 representa o alcance horizontal do eixo onde a variação da curva ocorre, a_2 representa a curvatura e a_3 é o termo de correção [9].

Uma forma alternativa do modelo representado em (2.6) pode ser obtida adicionando um termo extra p_t que representa a potência obtida na amostra anterior [9]:

$$p_{t+k} = a_0 \cdot \tanh\left(\frac{w_{t+k} - a_1}{a_2}\right) + b \cdot p_t a_3 \quad (2.7)$$

Redes Neurais Artificiais

Recentemente com o desenvolvimento da Inteligência Artificial (IA) novos métodos baseados em IA surgiram sendo um deles as Redes Neurais Artificiais (RNA). As RNA surgiram devido à sua capacidade de emular o cérebro humano

conseguindo desta forma solucionar problemas complexos uma vez que durante o processo de treino efetuam a sua aprendizagem para conseguirem fazer previsões.

As RNA são constituídas por unidades de processamento simples (neurónios) que têm uma propensão natural para armazenar conhecimento experimental. Estas redes assemelham-se ao cérebro humano na medida em que o conhecimento é adquirido pela rede a partir do ambiente envolvente e as interligações entre neurónios são usados para guardar conhecimento. Um modelo de um neurónio artificial é constituído por 3 elementos básicos e está representado na Figura 2.1 [11]:

- Conjunto de **sinapses** em que cada uma delas é caracterizada por um peso sináptico. As entradas x_i são multiplicadas pelos pesos sinápticos w_{ki}
- **Somador** que soma os sinais de entrada multiplicados pelos respetivos pesos sinápticos resultando em v_k
- **Função de Ativação** $\varphi(\cdot)$ que limita a amplitude da saída de um neurónio.

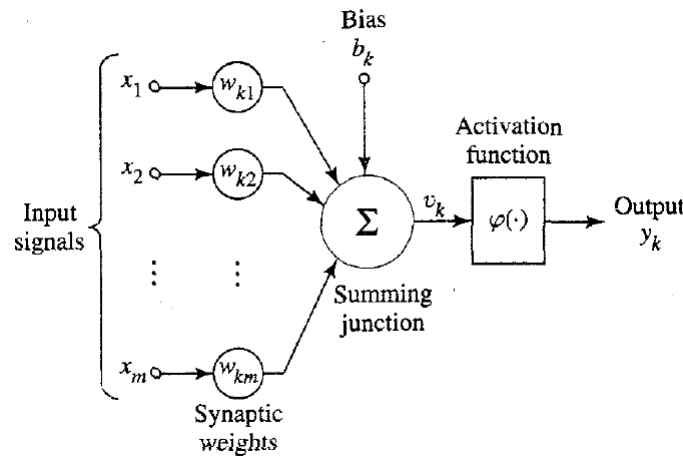


Figura 2.1: Esquema representativo de um neurónio artificial [11].

Na Figura 2.1 é possível verificar uma entrada de polarização b_k que é utilizada para aumentar ou diminuir a entrada da função de ativação consoante se é positiva ou negativa.

Generalizando e sabendo que o sinal de saída é a conjugação do sinal que sai do somador v_k após ser sujeito à função de ativação $\varphi(\cdot)$, na equação (2.8) está representado o sinal de saída:

$$y_k = \varphi \left(\sum_{i=1}^m w_{ki} \cdot x_i \right) \quad (2.8)$$

Algumas das **Funções de Ativação** utilizadas são:

- **Função escalão (*Step Function*)**

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq t \\ 0 & \text{se } v < t \end{cases} \quad (2.9)$$

- **Função linear por partes (*Piecewise-linear Function*)**

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq t \\ v & \text{se } \frac{1}{2} > v > -\frac{1}{2} \\ 0 & \text{se } v \leq -\frac{1}{2} \end{cases} \quad (2.10)$$

- **Função Sigmoidal (*Sigmoid Function*)**

$$\varphi(v) = \frac{1}{1 + e^{-v}} \quad (2.11)$$

- **Função Sign**

$$\varphi(v) = \begin{cases} +1 & \text{se } v \geq 0 \\ -1 & \text{se } v < 0 \end{cases} \quad (2.12)$$

Na Figura 2.2 é possível observar algumas das funções de ativação.




Figura 2.2: (a) Função escalão (b) Função linear por partes [11]

Modelos Difusos

Os sistemas difusos derivam de modelos clássicos binários em que a variável está compreendida no intervalo $[0,1]$ ao contrário dos modelos clássicos em que a variável assume apenas dois valores, 0 ou 1. No caso dos modelos difusos estes descrevem o sistema com alguma incerteza não se tratando de casos de “verdadeiro” e “falso”, mas sim de “pequeno”, “médio” ou “grande”. Este modelo consegue descrever sistemas incertos tornando o problema num problema qualitativo em vez de quantitativo [12].

O principal objetivo de um modelo difuso é definir um sistema a partir de regras do tipo [6]

$$: \text{If } u \text{ is } A_i \text{ then } y \text{ is } B_i \quad (2.13)$$

onde A_i são antecedentes e B_i são consequentes que correspondem às i regras, sendo u a variável de entrada e y a variável de saída.




Figura 2.3: (a) Modelo Tradicional e (b) Modelo *Fuzzy* representativos da altura [13].

Na figura 2.3 é possível observar a rigidez associada aos métodos tradicionais em comparação com o modelo difuso onde existe mais liberdade para classificar a altura em vez de "alto" e "não alto".

2.1.3 Modelos Híbridos

Recentemente foram desenvolvidas algumas abordagens que têm por base a combinação de vários modelos denominando-se modelos híbridos. O objetivo destes modelos é tirar partido das vantagens de cada um dos modelos para se obter melhores resultados de predição [14].

Estes modelos combinam diferentes abordagens, como por exemplo a combinação dos modelos físicos com os modelos estatísticos, e ainda a combinação de modelos de curto horizonte temporal com modelos de médio horizonte temporal [15].

Os modelos híbridos podem ser combinados da seguinte forma [15]:

- Combinação de modelos físicos e estatísticos;
- Combinação de modelos de curto e médio horizonte temporal.

2.2 Filtros

Para a aplicação dos modelos de previsão é necessário que o conjunto de dados a tratar seja o mais aproximado da realidade possível, para isso acontecer é necessário submeter o conjunto de dados a uma filtragem que irá eliminar possíveis falhas no sistema de medida obtidas durante a sua recolha, desta forma a eficiência da previsão não é comprometida.

Filtro de Média Móvel

O filtro de média móvel é o filtro digital mais simples de entender e usar. Apesar da sua simplicidade este filtro é ideal para atenuar o ruído, no entanto pode produzir distorções significativas e reduzir a amplitude do sinal. Como o nome indica, o filtro de média móvel calcula a média de um número de pontos do sinal de entrada para gerar pontos no sinal de saída. Este procedimento é repetido para que a janela deslizante M amostras seja usada para calcular a média de todo o conjunto de dados [16].

A equação matemática que representa o filtro é dada por:

$$y[i] = \frac{1}{M} \sum_{j=0}^{M-1} x[i+j] \quad (2.14)$$

Onde $x[]$ representa o sinal de entrada, $y[]$ representa o sinal de saída e M representa o número de amostras usadas para o cálculo da média.

Filtro Passa-baixo de Primeira Ordem

Este tipo de filtros são bastante conhecidos pela sua simplicidade e capacidade de atenuação de ruído indesejável. Por forma a atenuar o ruído do sinal a equação 2.15 é aplicada [17]:

$$y(n) = a \cdot y(n-1) + b \cdot x(n) \quad (2.15)$$

Onde $y(n)$ corresponde ao sinal de saída, $y(n-1)$ corresponde à amostra anterior, $x(n)$ corresponde ao sinal de entrada e a, b são constantes. Sabemos ainda que a constante $b = 1 - a$. Sabemos que o efeito do filtro é maximizado quando a constante a se aproxima da unidade o que leva a uma maior atenuação do ruído, a influência desta constante é observada na Figura 2.4.

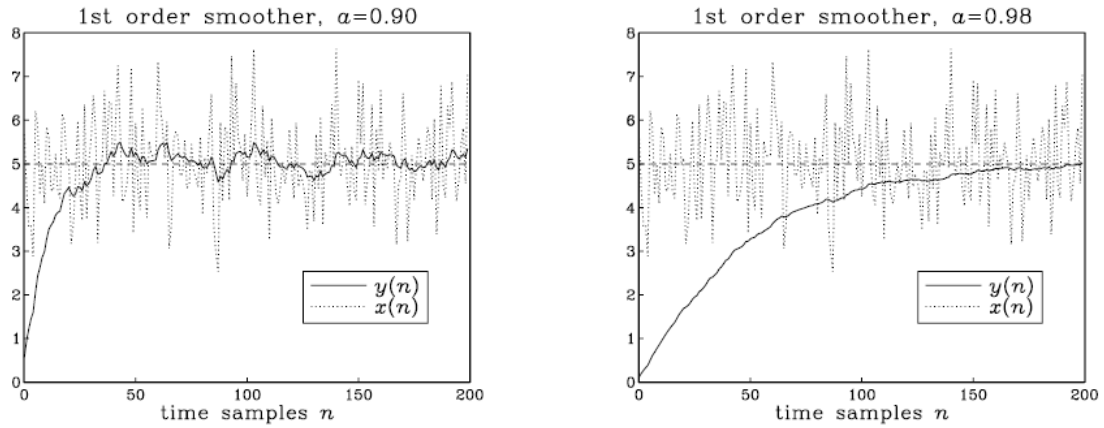


Figura 2.4: Efeito da constante a no sinal de saída [17].

2.3 Trabalhos Relacionados

Como discutido anteriormente a previsão da energia eólica é de extrema importância, e por esse motivo é cada vez mais alvo de estudo com o intuito de melhorar os resultados obtidos pelos modelos de previsão.

Em [10] foi criado um modelo para prever a potência eólica usando dados provenientes do modelo NWP, neste caso o *High-Resolution Limited Area Model* (HIRLAM) tendo em conta a topografia do local e, para corrigir o modelo NWP foi usado o modelo *Wind Atlas Application and Analysis Program* (WASP). No caso em estudo a correção baseada no modelo WASP apresentou piores resultados que o caso sem correção. Conclui-se ainda que o modelo de estimativa por regressão linear produz melhores resultados.

Em [9] recorreram a modelos físicos e estatísticos para obter melhores resultados para a previsão, concluindo que todos os modelos apresentados obtiveram bons resultados mas que o modelo baseado em equações não-polinomiais tem mais vantagens uma vez que é mais sensível a variações da inclinação da curva de potência prevista.

Em [18] é usado um modelo NWP, *Brazilian developments on the Regional Atmospheric Modelling System* (BRAMS) os valores obtidos para a velocidade do vento são posteriormente usados por modelos de regressão estatísticos e curva de potência. Este modelo obteve bons resultados e foi considerado viável para casos em tempo real de previsão eólica.

Devido ao elevado investimento na produção de energia elétrica baseada em recursos eólicos foi necessário a criação de modelos para efetuar a sua previsão. De seguida serão abordados alguns dos modelos que se encontram atualmente disponíveis no mercado.

- **Previento** (Físico)

O Previento é um sistema para previsão de energia eólica que foi desenvolvido na *University of Oldenburg*. Este sistema é baseado em modelos físicos e utiliza como entrada os dados provenientes do NWP para o cálculo da velocidade do vento à altura da turbina. A previsão feita pelo modelo NWP é mais tarde ajustada tendo em conta as especificidades do local como a rugosidade do terreno. Para o cálculo final da energia produzida no parque eólico é tida em conta a curva de potência das turbinas no local. É ainda importante referir que este sistema consegue fazer previsões para horizontes temporais de até 48h [19].

- **WPPT** (Estatístico)

O *Wind Power Prediction Tool* (WPPT) foi desenvolvido na *Technical University of Denmark* (DTU) e é um sistema de previsão que consegue prever para um único parque eólico, para um grupo de parques ou ainda para uma região. A abordagem consiste em dividir as áreas em sub-áreas em que cada uma destas representa um parque eólico. Desta forma é feita uma previsão para a sub-área que mais tarde será utilizada para o cálculo da área total. Este modelo consegue prever com certeza para horizontes temporais de até 48h com intervalos de tempo de 30m, dependendo do horizonte temporal do modelo NWP.

É usada uma abordagem por 2 ramos para prever toda a área. No primeiro ramo, a previsão para os parques eólicos na sub-área i é realizada com base em medições on-line e no modelo NWP; de seguida, as previsões obtidas para os parques na sub-área i são somadas e escaladas por forma a obter a previsão total para a sub-área i e consequentemente a previsão total da área é calculada através da soma de todas as previsões da sub-área. No segundo ramo, a previsão para cada sub-área i é calculada da mesma forma que no ramo 1 mas com base em dados off-line. A previsão final para a área é calculada por uma média ponderada das previsões obtidas em cada ramo [20].

- **Sipreólico** (Estatístico)

O sistema Sipreólico foi desenvolvido pela *Universidad Carlos III* devido ao elevado crescimento do setor da energia eólica em Espanha. Este sistema baseia-se em previsões meteorológicas do HIRLAM e informações disponibilizadas pelo SCADA. Estes resultados são usados como entrada para uma combinação de diversos modelos estatísticos. Este sistema consegue fazer previsões para um horizonte temporal de até 36h com um intervalo de tempo de 1h. Este sistema foi construído de modo a que se consiga apresentar uma previsão mesmo quando dados online não estão disponíveis tendo por base apenas características da turbina eólica e dos dados obtidos pelo NWP. São 9 os modelos usados neste sistema e provêm de diferentes grupos. No primeiro grupo temos os modelos que recorrem a equações polinomiais de diferentes graus para converter a velocidade do vento em potência. No segundo grupo temos os modelos não-paramétricos baseados em polinómios semelhantes ao modelo WPPT [20].

- **AWPPS** (Estatístico)

O sistema AWPPS (*ARMINES Wind Power Prediction System*) encontra-se inserido no MORE-CARE EMS software e está operacional na zona da Madeira e da Grécia. Este sistema integra vários tipos de modelos: modelo de curto horizonte temporal, longo horizonte temporal e modelo combinado. Todos estes modelos se baseiam em modelos estatísticos nomeadamente redes neuro-difusas, que consiste num sistema que conjuga as redes neuronais com regras dos sistemas difusos. No caso da Madeira, os dados online são providenciados pelo sistema SCADA, o sistema implementado providencia previsões para os parques eólicos da ilha da Madeira com um horizonte temporal de até 8h [20], [22].

- **Zephyr** (Híbrido)

O sistema *Zephyr* é uma junção do WPPT e do *Prediktor*(modelo físico desenvolvido na Dinamarca) é por isso considerado um modelo híbrido, esta combinação de modelos tem como objetivo aumentar a eficiência da previsão tirando partido das vantagens de ambos os modelos. Neste sistema dependendo dos dados disponíveis para o local é escolhido o modelo para efetuar a previsão. Se os únicos dados disponíveis para o local forem o número, tipo e localização das turbinas então o modelo *Prediktor* é usado tendo em conta os dados provenientes do NWP. No caso de existirem muitos dados disponíveis incluindo dados *online* das turbinas então o modelo estatístico WPPT é utilizado [21].

Na tabela 2.1 pode-se observar um resumo dos modelos que foram abordados anteriormente.

Tabela 2.1: Quadro resumo dos modelos abordados.

Modelo	Tipo de Modelo	Localização
Previento	Físico	Alemanha
WPPT	Estatístico	Dinamarca
Sipreólico	Estatístico	Espanha
AWPPS	Estatístico	Madeira e Grécia
Zephyr	Híbrido	Dinamarca

2.4 Sinopse

Neste capítulo foram abordados os diferentes modelos de previsão existentes: físicos, estatísticos e híbridos. Os modelos físicos caracterizam-se por modelos que apenas têm por base equações físicas para o cálculo da predição. Os modelos estatísticos baseiam-se em dados do passado para encontrar uma relação com o presente e futuro, sendo para isso necessário encontrar uma equação que descreva a relação dos valores de entrada com os valores de saída para o cálculo da previsão. Por último, temos os modelos híbridos que consistem na junção de mais do que um modelo por forma a tirar vantagens de ambos os modelos.

Para que estes modelos de previsão obtenham resultados mais precisos é necessário fazer um tratamento dos dados de entrada, para isso é necessário recorrer a filtros para filtrar amostras indesejadas. Neste capítulo foram abordados 2 tipos de filtros: o filtro de média móvel e o filtro passa-baixo de 1ª ordem. No fim deste capítulo foram abordados alguns trabalhos já realizados sobre os modelos em estudo e também sobre modelos que se encontram já implementados no mercado.

METODOLOGIA

Neste capítulo será abordado todo o processo realizado ao longo da dissertação até ao desenvolvimento do modelo de previsão de potência e à construção da aplicação.

3.1 Metodologia Adotada




Figura 3.1: Arquitetura do sistema.

Como foi referido anteriormente na secção 1.2 um dos objetivos desta dissertação é o desenvolvimento de um modelo de previsão da produção de potência, por conversão de eólica. Para atingir este objetivo é necessário seguir algumas etapas. Após o desenvolvimento do modelo é necessário proceder à construção da aplicação que é também um dos objetivos desta dissertação.

Na Figura 3.1 é possível observar de uma forma geral a metodologia adotada. Para se conseguir atingir os objetivos é necessário seguir algumas etapas:

- **Dados previamente recolhidos** - Para o desenvolvimento do modelo é necessário dados de entrada no sistema, neste caso não foi necessário proceder à aquisição dos dados uma vez que os dados foram previamente recolhidos.

- **Seleção do Modelo de Previsão** - Nesta etapa foi necessário proceder à seleção do Modelo a implementar, para isso foi feita uma análise dos dados existentes e desta forma foi escolhido o modelo mais adequado.
- **Filtragem e Processamento dos Dados** - Etapa em que os dados de entrada no sistema sofrem todo o processo de filtragem e processamento para poderem dar entrada no sistema.
- **Treino e Validação do Modelo** - O modelo é construído com os dados previamente recolhidos e é por fim testado o seu desempenho usando dados reais e comparando com os valores obtidos.
- **Construção de Aplicação/Interface com o Utilizador** - Na última etapa do sistema é construída uma aplicação que permite ao utilizador selecionar o horizonte temporal, o mês e o tipo de modelo a utilizar. Esta aplicação fornece ainda ao utilizador a previsão para o período selecionado na forma gráfica.

As etapas descritas anteriormente podem ser observadas na Figura 3.2.

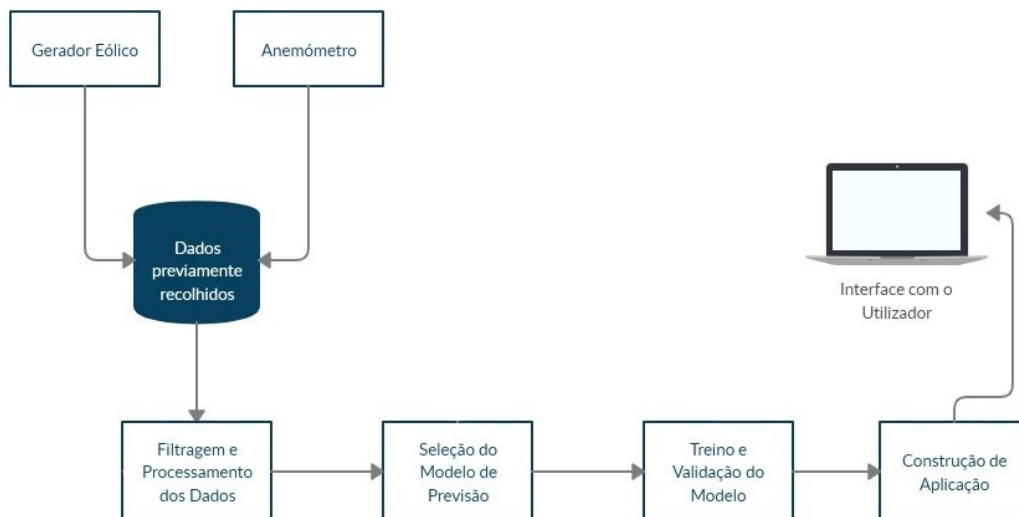


Figura 3.2: Metodologia adotada.

3.2 Recolha de Dados e Seleção das Variáveis de Entrada no Sistema

Nesta secção é abordado o processo de recolha de dados e os instrumentos utilizados, por fim são seleccionadas as variáveis de entrada utilizadas para o modelo de previsão.

3.2.1 Recolha de Dados

Como referido anteriormente a construção de modelos de previsão estatísticos depende de um conjunto de dados de longa duração. Neste caso os dados foram previamente recolhidos pela estação meteorológica que se encontra instalada no topo do DEEC. Os dados meteorológicos recolhidos são constituídos por informação sobre a temperatura, a velocidade e direção do vento, e a irradiância. A estação meteorológica é constituída por um anemómetro, um termómetro e um piranómetro. O gerador eólico encontra-se também no topo do edifício mas não está junto da estação meteorológica.

Os dados utilizados são referentes ao período desde Setembro de 2012 a Janeiro de 2014.

3.2.1.1 Anemómetro

Na Figura 3.3 é possível observar o anemómetro instalado no edifício e as suas especificações podem ser observadas na Tabela 3.1.




Figura 3.3: Anemómetro *Davis Cup* instalado na Estação meteorológica.

Tabela 3.1: Especificações do Anemómetro.

Alcance	
Direção do vento (°)	0-360
Velocidade do vento (m/s)	0-58
Precisão	
Direção do vento (%)	± 7
Velocidade do vento (%)	± 5

3.2.1.2 Gerador Eólico

O gerador eólico alvo de estudo e, que se encontra instalado no topo do DEEC, é da marca Yangzhou Shenzhou Wind-driven Generator Co., modelo FD3.6-2000-10L e pode ser observado na figura 3.4.



Figura 3.4: Gerador Eólico instalado no topo do DEE.

As especificações fornecidas pelo fabricante podem ser observadas na tabela 3.2 [23].

Tabela 3.2: Especificações do Gerador Eólico FD3.6-2000-10L.

Potência Nominal (W)	2000
Tensão Nominal (V)	120
Velocidade de <i>cut-in</i> (m/s)	3
Velocidade nominal do vento (m/s)	9
Velocidade de <i>cut-out</i> (m/s)	16

3.2. RECOLHA DE DADOS E SELEÇÃO DAS VARIÁVEIS DE ENTRADA NO SISTEMA

O gerador eólico é ligado a um retificador/inversor, depois do sinal retificado os dados são recolhidos pelo contador de energia presente na cave do departamento e que pode ser observado na figura 3.5.

3.2.1.3 Contador de Energia

Os dados referentes à produção de energia proveniente do Gerador Eólico resultam de um contador que se encontra ligado ao gerador no topo do DEE. O contador de energia é da marca Algodue Eletronica modelo UPT210, que se encontra representado na figura 3.5.



Figura 3.5: Contador de Energia referente à produção eólica.

As amostras são recolhidas com intervalos de 1 minuto.

3.2.2 Sinopse

A produção de energia eólica é contabilizada pelo contador de energia o que origina os dados de produção. Da mesma forma os dados meteorológicos têm origem na estação meteorológica mais concretamente no anemómetro. Estas 2 bases de dados vão ser utilizadas no *Script Matlab* desenvolvido que inclui as etapas de filtragem e processamento dos dados, construção do modelo e validação do modelo. Este *Script* é utilizado para desenvolver uma aplicação que permite ao utilizador a visualização da previsão para determinado período.

Após análise da arquitetura do sistema concluiu-se que a variável de entrada do modelo deve ser a velocidade do vento e a variável de saída a potência eólica.

A arquitetura geral do sistema é apresentada na figura 3.6.

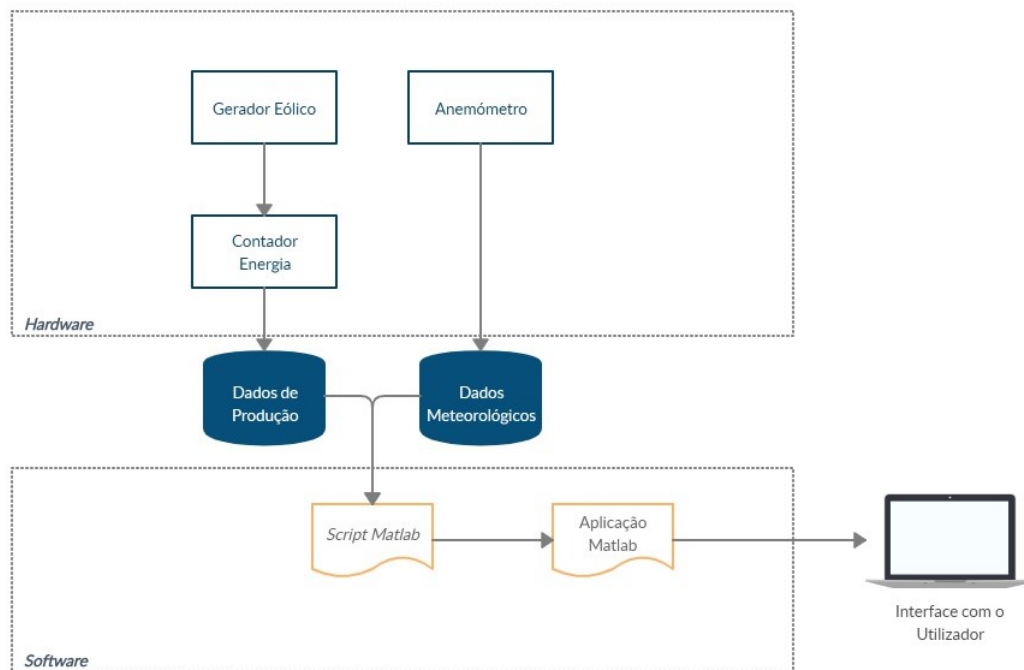


Figura 3.6: Arquitetura geral do Sistema.

3.3 Script Matlab

Esta secção incorpora toda a parte desenvolvida em *Matlab* desde o tratamento e filtragem dos dados até ao treino e validação do modelo.

A figura 3.7 representa a organização do *script* desenvolvido.

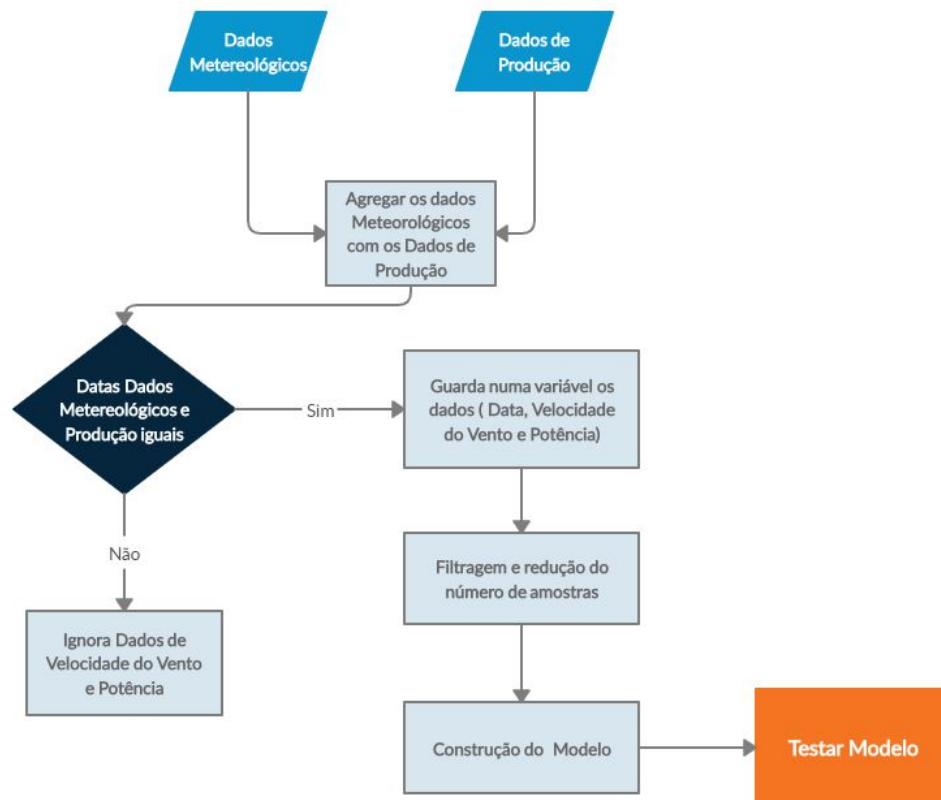


Figura 3.7: Script desenvolvido.

Primeiramente os dados meteorológicos (data, velocidade do vento) e os dados de produção (data, potência) entram no sistema e é necessário fazer a ligação entre os mesmos para se conseguir construir o modelo. São comparadas as datas dos dados meteorológicos com as datas dos dados de produção para se conseguir saber a potência obtida para determinada velocidade do vento, os *match* encontrados entre estes dois conjuntos de dados são armazenados numa variável que posteriormente será usada para a construção do modelo.

Antes dos dados poderem ser usados para construir o modelo é necessário submetê-los a um processo de filtragem e redução de amostras. Após a filtragem procede-se à construção do modelo utilizando os dados de entrada filtrados (velocidade do vento) e os dados de saída (produção), por fim é testado o modelo.

3.3.1 Tratamento dos Dados

Uma vez sabendo os dados de entrada do sistema e definido o modelo a implementar é necessário avaliar o comportamento dos dados e decidir sobre os processos de filtragem necessários para atenuar o ruído indesejável. Começou por se analisar o comportamento da velocidade do vento para decidir qual o tipo de processamento necessário para assegurar o bom funcionamento do modelo.




Figura 3.8: Variação da velocidade do vento ao longo de 1 semana.

Analisando a Figura 3.8 é possível observar as variações bruscas de valores na velocidade do vento, estas características têm impacto negativo no modelo uma vez que dificulta a sua aprendizagem. Desta forma é necessário proceder a um processo de filtragem de dados que será constituído por 3 etapas: redução do número de amostras, eliminação de *outliers* e aplicação de filtros.

3.3.1.1 Redução do número de amostras

Devido ao comportamento instável associado à velocidade do vento é necessário optar por um método de redução de amostras com o intuito de suavizar o comportamento dos dados e facilitar a construção do modelo.

Optou-se por desenvolver um *script* recorrendo ao *software Matlab* que permite definir o intervalo entre amostras e realiza o cálculo da média das amostras originais durante esse período z .

A equação 3.1 foi aplicada aos dados originais para reduzir o número de amostras preservando o seu comportamento.

$$x(i) = \frac{\sum_{k=z}^{k=0} x(i-k)}{z} \quad (3.1)$$

Neste caso optou-se por utilizar um $z = 15$, o que reduziu as amostras ao minuto para amostras de 15 em 15 minutos.

Na Figura 3.9 é possível observar os resultados obtidos com a redução do número de amostras.




Figura 3.9: Comparação dos dados originais com a redução de amostras.

3.3.1.2 Remoção de Outliers

Após análise dos dados é necessário proceder à eliminação de *outliers* para conseguir construir o modelo. Eliminou-se todas as amostras que não se inseriam nas especificações definidas, definiu-se um filtro em que só eram consideradas as amostras em que a potência seja superior a 1 ou a velocidade do vento fosse 0. Desta forma só seriam consideradas amostras em que a potência assume o valor 0 quando a velocidade do vento fosse 0.

Na Figura 3.10 é possível observar as amostras eliminadas recorrendo ao filtro definido anteriormente, que se encontram representadas a azul.




Figura 3.10: Comparação dos dados originais com a eliminação de *outliers*.

3.3.1.3 Filtros

Com os processos de filtragem definidos anteriormente como a redução de amostras e a eliminação de *outliers* é possível atenuar o ruído dos dados originais, no entanto estes ainda apresentam alterações bruscas pelo que é necessário proceder à aplicação de um filtro para suavizar os dados sem perder informação importante.

Anteriormente na secção 2.2 foram discutidos vários tipos de filtros disponíveis, optou-se por usar o filtro da média móvel, que suaviza os dados uma vez que o ponto é substituído pela média dos M pontos vizinhos, neste caso recorreu-se a 2 janelas deslizantes uma de $M=3$ e outra de $M=10$ pontos.




Figura 3.11: Aplicação do filtro da média móvel com várias janelas deslizantes.

Na figura 3.11 é possível observar os resultados obtidos recorrendo ao filtro da média móvel em comparação com os dados originais aplicados à velocidade do vento.

3.3.2 Seleção do Modelo de Previsão

Após a escolha das variáveis de entrada é necessário proceder à escolha do modelo a estudar, a escolha recaiu sobre os modelos estatísticos uma vez que estes modelos apresentam bons resultados quando existem dados históricos com alguma extensão. Na secção 2.1.2 foram abordados vários modelos estatísticos usados para a previsão da produção de energia eólica, nesta dissertação foram implementados 2 modelos com o objetivo de testar a sua aplicabilidade no local em estudo. Para o caso da previsão da produção de energia eólica é necessário ter em conta a velocidade do vento, sabemos ainda que esta apresenta grande variabilidade. A escolha destes modelos teve em conta a variabilidade do vento e por isso a necessidade de um modelo que seja altamente sensível a variações. Desta forma optou-se por selecionar 2 modelos que se baseiam em equações completamente distintas o que pode permitir tirar conclusões sobre a sua adaptabilidade a variações do vento.

Os modelos escolhidos foram o modelo de estimativa por regressão polinomial e o modelo de estimativa baseada em equações não-polinomiais.

Como primeiro modelo (M1) temos o modelo de estimativa por regressão polinomial que é descrito pela equação 3.2.

$$p_{t+k} = a_k w_{t+k} + b_k w_{t+k}^2 + c_k w_{t+k}^3 + l_k + e_{t+k} \quad (3.2)$$

Para a implementação deste modelo é necessário recorrer ao *software Matlab* para obter as constantes necessárias para a construção do modelo, recorreu-se à função *lsqcurvefit* que consegue calcular as constantes de uma determinada equação fazendo o *curve-fitting* aos dados em questão do ponto de vista do método dos mínimos quadrados, desta forma a equação utilizada é igual à equação descrita em 3.2 com exceção da última parcela que é representativa do erro.

Após a implementação da equação que descreve o modelo é necessário fornecer-lhe os dados de entrada (velocidade do vento) e de saída (potência) do sistema para se conseguir obter as constantes, os dados utilizados nesta etapa são os dados referentes ao conjunto de treino. Por último é aplicada a equação do modelo já com as constantes calculadas aos dados de entrada do sistema e é obtido uma estimativa para a saída do mesmo. Posteriormente deve-se proceder à validação

do modelo comparando os dados obtidos com os dados reais e calculando o erro associado à previsão.

Na figura 4.4 é possível observar o polinómio calculado para um mês do conjunto de treino.




Figura 3.12: Polinómio calculado para o M1 para um mês do conjunto de treino.

O segundo modelo implementado (M2) corresponde à estimativa baseada em equações não polinomiais e é descrito pela equação 3.3.

$$p_{t+k} = a_0 \cdot \tanh\left(\frac{w_{t+k} - a_1}{a_2}\right) + a_3 \quad (3.3)$$

O procedimento adotado para a construção do modelo foi similar ao M1 e o polinómio obtido pode ser observado na figura 4.12.

Os modelos implementados vão ser aplicados a horizontes temporais de curto, médio e de longo prazo por forma a concluir sobre a sua aplicabilidade.




Figura 3.13: Polinômio calculado para o M2 para um mês do conjunto de treino.

3.3.3 Treino e Validação do Modelo

O maior problema nas previsões baseadas em modelos estatísticos é o cálculo dos coeficientes dos modelos. Estes coeficientes representam as características do local em estudo e por isso para a previsão assume-se que o seu comportamento será similar durante o período em estudo. Por forma a obter os coeficientes, os dados históricos existentes são divididos em 2 grupos que correspondem ao conjunto de treino e ao conjunto de teste/validação. Com o conjunto de treino, e tendo em conta que temos as variáveis de entrada e de saída do sistema, é possível construir o modelo. Após a construção do modelo é necessário testá-lo e proceder à sua validação.

O teste do modelo é feito usando os dados do conjunto de teste, as variáveis de entrada são inseridas no modelo e os resultados obtidos pelo modelo são por fim comparados com os dados reais.

Na Figura 3.14 é possível observar o processo de treino e validação do modelo.

Para avaliar o desempenho dos modelos e poder fazer uma comparação entre os mesmos é necessário recorrer a vários indicadores estatísticos. Os indicadores estatísticos utilizados foram o MAPE (*Mean Absolute Percent Error*), que mede a percentagem de erro na previsão, e o RMSE (*Root Mean Square Error*) que representa o desvio padrão médio entre os valores previstos e os valores reais. O cálculo dos indicadores pode ser feito recorrendo às equações 3.4 e 3.5:

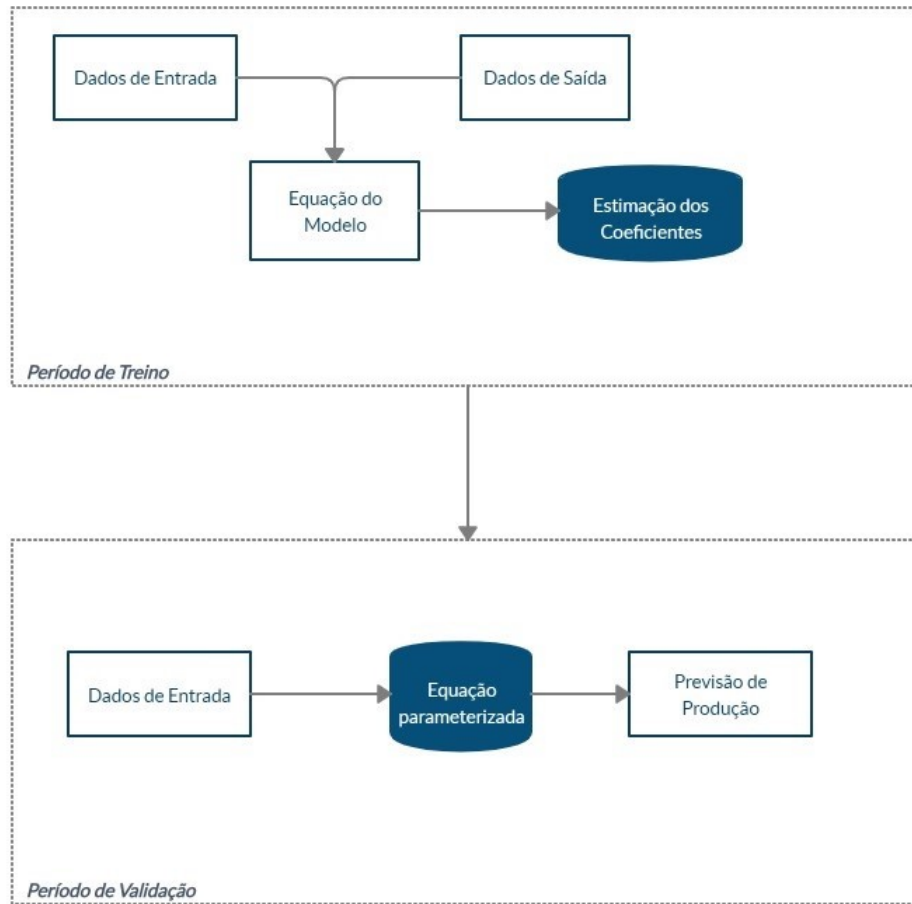


Figura 3.14: Período de Treino e de Validação do Modelo.

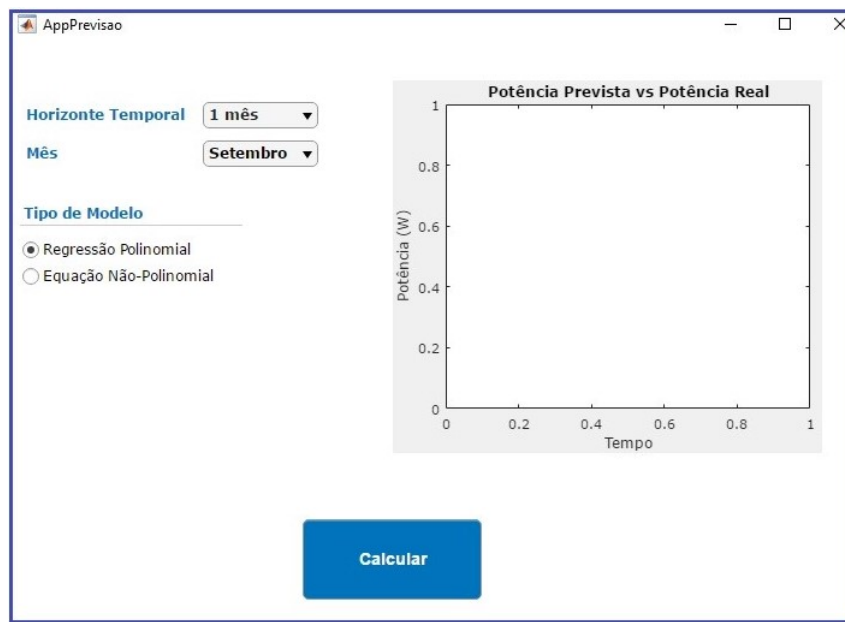
$$MAPE = \left(\frac{1}{n} \sum \frac{|Real - Previsão|}{|Real|} \right) \times 100 \quad (3.4)$$

$$RMSE = \sqrt{\frac{1}{n} \sum (Real - Previsão)^2} \quad (3.5)$$

Os testes serão utilizados para testar ambos os modelos em vários horizontes temporais, estes indicadores apresentam valores mais próximos de 0 quando as previsões são mais precisas.

3.3.4 Interface com o Utilizador

Por último desenvolveu-se uma aplicação que permite ao utilizador um acesso facilitado aos resultados da previsão. O utilizador tem a oportunidade de seleccionar o mês, horizonte temporal e o modelo que quer simular, como é possível observar na figura 3.15.

Figura 3.15: Aplicação desenvolvida em *Matlab*.

Na aplicação não estão implementados todos os meses por inexistência de dados suficientes uma vez que a base de dados se encontra com lacunas relativamente aos dados de produção e meteorológicos.

Após clicar em calcular é corrido em *background* o *script* desenvolvido e é apresentado de forma gráfica os resultados da previsão em comparação com os dados reais para o mesmo período. Os resultados da simulação podem ser observados na figura 3.16.

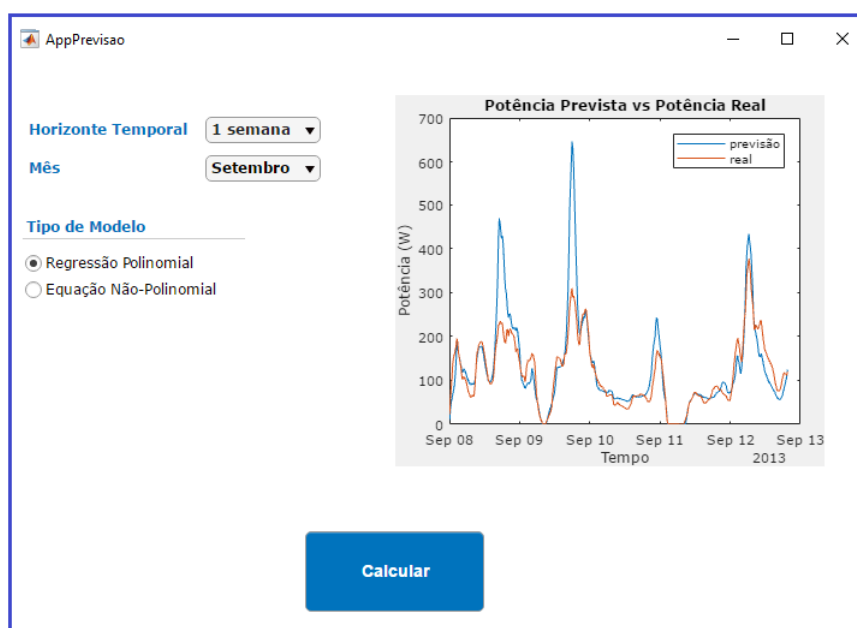


Figura 3.16: Simulação para o mês de Setembro com o modelo de Regressão Polinomial.

TREINO E VALIDAÇÃO

Neste capítulo é realizado o desenvolvimento dos 2 modelos de previsão referidos anteriormente, são treinados e testados para vários horizontes temporais e comparados entre si. No final é ainda feita uma análise do seu desempenho recorrendo aos indicadores estatísticos.

4.1 Desenvolvimento do Modelo de Regressão Polinomial

Ao longo desta secção será exemplificado todo o processo até à obtenção da previsão para o mês de Setembro de 2013 com vários horizontes temporais.

A previsão pode ser feita para diferentes horizontes temporais, nesta dissertação serão testados horizontes de curto, médio e longo horizonte temporal. Os horizontes temporais testados são de 1 mês, 1 semana, 1 dia, 12h e 6h.

4.1.1 Horizonte Temporal- 1 mês

A previsão mensal é feita tendo em conta o polinómio obtido para o mês de Setembro de 2012, que faz parte do conjunto de treino do modelo. Para esta dissertação será calculado um polinómio para cada mês a realizar previsão.

Começou por se analisar a variável de entrada (velocidade do vento) para o mês de Setembro de 2012, que se pode observar na Figura 4.1.




Figura 4.1: Velocidade do vento mensal para o mês de Setembro de 2012.

Como é possível observar os dados apresentam variações bruscas nos valores e ainda um período de 10 dias em que não existem dados. Estas lacunas nos dados comprometem os resultados uma vez que como existe falta de dados o modelo não aprende na sua totalidade o que contribui para erros maiores na previsão. A falha nos dados pode estar relacionada com o mau funcionamento dos equipamentos de aquisição dos dados.

De seguida analisou-se a potência para o mesmo período como se pode observar na figura 4.2.




Figura 4.2: Potência mensal para o mês de Setembro de 2012.

4.1. DESENVOLVIMENTO DO MODELO DE REGRESSÃO POLINOMIAL

Procedeu-se ao processo de tratamento de dados que inclui a redução do número de amostras pela aplicação da média, da eliminação de outliers e da aplicação do filtro de média móvel com 3 pontos. Os resultados obtidos após o tratamento dos dados pode ser observado na figura 4.3 .




Figura 4.3: Potência e velocidade do vento mensal para o mês de Setembro de 2012 após o tratamento de dados.

Fornecendo ao modelo a variável de entrada e saída é possível obter os coeficientes do modelo. A equação que representa o modelo está descrita em 4.1.

$$p_{t+k} = 23,3098 \cdot w_{t+k} + 0,7188 \cdot w_{t+k}^2 + 1,3108 \cdot w_{t+k}^3 - 0,0953 \quad (4.1)$$

O modelo obtido pode ser observado na figura 4.4.




Figura 4.4: Polinômio obtido após treino do modelo para o mês de Setembro de 2012.

Usando a equação do polinômio obtido durante o período de treino e fornecendo-lhe os dados de entrada relativamente à velocidade do vento para o mês de Setembro de 2013 obteve-se a previsão mensal da potência que se pode observar na figura 4.5. De salientar que os dados de entrada fornecidos para o teste do polinômio sofreram o mesmo processo de tratamento de dados utilizado no período de treino.




Figura 4.5: Previsão da potência para o mês de Setembro de 2013.

4.1.2 Horizonte Temporal- 1 semana

No caso da previsão semanal é usado o polinómio obtido para a previsão mensal, neste caso foi selecionado o mês de Setembro de 2012 para prever a segunda semana do mês de Setembro de 2013.

O procedimento realizado é similar ao descrito para a previsão mensal, o polinómio obtido pode ser observado na figura 4.4.

Os resultados obtidos para a previsão da segunda semana de Setembro de 2013 pode-se observar na Figura 4.6.




Figura 4.6: Previsão da potência para a semana de Setembro de 2013.

4.1.3 Horizonte Temporal- 1 dia

Na previsão com horizonte temporal de 1 dia é utilizado o polinómio obtido para o horizonte temporal de 1 semana, neste caso é utilizado o polinómio obtido para a primeira semana de Setembro de 2012 para prever o dia 8 de Setembro de 2013.

A equação do polinómio está representada em 4.2.

$$p_{t+k} = 23,5753 \cdot w_{t+k} - 2,1803 \cdot w_{t+k}^2 + 2,0603 \cdot w_{t+k}^3 + 0,3578 \quad (4.2)$$

O polinómio utilizado está representado na Figura 4.7 .




Figura 4.7: Polinômio obtido após o treino do modelo para a semana de Setembro de 2012.

Os resultados obtidos para a previsão diária de Setembro de 2013 estão representados na Figura 4.8.




Figura 4.8: Previsão diária de Setembro de 2013.

4.1.4 Horizonte Temporal- 12 Horas

Na previsão com horizonte temporal de 12 Horas é usado o polinômio obtido para o horizonte temporal de 1 dia, neste caso é utilizado o polinômio obtido para o dia 1 de Setembro de 2012 para prever as primeiras 12 Horas do dia 8 de Setembro de 2013.

A equação do polinômio está representada em 4.3.

$$p_{t+k} = -253,8049 \cdot w_{t+k} + 66,3743 \cdot w_{t+k}^2 - 2,9676 \cdot w_{t+k}^3 + 317,8016 \quad (4.3)$$

O polinômio utilizado está representado na figura 4.9 .




Figura 4.9: Polinômio obtido após o treino do modelo para o dia 1 de Setembro de 2012.

Os resultados obtidos para a previsão de 12 Horas de Setembro de 2013 estão representados na Figura 4.10.




Figura 4.10: Previsão diária de Setembro de 2013.

4.1.5 Horizonte Temporal- 6 Horas

Na previsão com horizonte temporal de 6 Horas é usado o polinómio obtido para o horizonte temporal de 1 dia, neste caso é utilizado o polinómio obtido para o dia 1 de Setembro de 2012 para prever as primeiras 6 Horas do dia 8 de Setembro de 2013.

O polinómio utilizado está representado na Figura 4.9 .

Os resultados obtidos para a previsão de 6 Horas de Setembro de 2013 estão representados na Figura 4.11.

4.2. DESENVOLVIMENTO DO MODELO DE PREVISÃO BASEADO EM EQUAÇÕES NÃO-POLINOMIAIS




Figura 4.11: Previsão diária de Setembro de 2013.

4.2 Desenvolvimento do Modelo de Previsão baseado em Equações Não-Polinomiais

Ao longo desta secção será exemplificado todo o processo até à obtenção da previsão para o mês de Setembro de 2013 com vários horizontes temporais.

As previsões realizadas nesta secção são idênticas às realizadas na secção 4.1 o que difere é a equação do polinómio.

4.2.1 Horizonte Temporal- 1 mês

A equação do polinómio obtido está representada em 4.4.

$$p_{t+k} = 2584,5209 \cdot \tanh\left(\frac{w_{t+k} - 11,6332}{5,0477}\right) + 2533,2943 \quad (4.4)$$

O polinómio obtido para o mês de Setembro de 2012 está representado na Figura 4.12.




Figura 4.12: Polinômio obtido após treino do modelo para o mês de Setembro de 2012.

Obteve-se a previsão mensal da potência que se pode observar na Figura 4.13.




Figura 4.13: Previsão da potência para o mês de Setembro de 2013.

4.2.2 Horizonte Temporal- 1 semana

O polinômio utilizado pode ser observado na Figura 4.12.

Os resultados obtidos para a previsão da segunda semana de Setembro de 2013 pode-se observar na Figura 4.14.




Figura 4.14: Previsão da potência para a semana de Setembro de 2013.

4.2.3 Horizonte Temporal- 1 dia

A equação do polinômio obtido está representada em 4.5.

$$p_{t+k} = 2638,7098 \cdot \tanh\left(\frac{w_{t+k} - 10,6114}{4,2735}\right) + 2601,5655 \quad (4.5)$$

O polinômio utilizado está representado na figura 4.15 .




Figura 4.15: Polinômio obtido após o treino do modelo para a semana de Setembro de 2012.

Os resultados obtidos para a previsão diária de Setembro de 2013 estão representados na Figura 4.16.




Figura 4.16: Previsão diária de Setembro de 2013.

4.2.4 Horizonte Temporal- 12 Horas

A equação do polinômio obtido está representada em 4.6.

$$p_{t+k} = 248,3069 \cdot \tanh\left(\frac{w_{t+k} - 4,8477}{1,0858}\right) + 318,9207 \quad (4.6)$$

O polinômio utilizado está representado na Figura 4.17 .




Figura 4.17: Polinômio obtido após o treino do modelo para o dia 1 de Setembro de 2012.

Os resultados obtidos para a previsão de 12 Horas de Setembro de 2013 estão representados na Figura 4.18.




Figura 4.18: Previsão diária de Setembro de 2013.

4.2.5 Horizonte Temporal- 6 Horas

O polinómio utilizado está representado na Figura 4.17 .

Os resultados obtidos para a previsão de 6 Horas de Setembro de 2013 estão representados na Figura 4.19.




Figura 4.19: Previsão diária de Setembro de 2013.

4.3 Resultados dos Indicadores Estatísticos para os 2 modelos

Nesta secção são abordados os resultados obtidos para o mês de Setembro recorrendo aos indicadores estatísticos mencionados na secção 3.3.3.

Fazendo a análise da Figura 4.20 é possível constatar que o erro é maior para horizontes temporais mais longos, como seria de esperar visto que os modelos de previsão estatísticos são mais utilizados para horizontes de curto prazo.

Pode-se concluir que só faz sentido utilizar os modelos para horizontes temporais até às 12 horas, uma vez que para horizontes maiores o erro é demasiado elevado para as previsões. De um modo geral os resultados foram melhores utilizando o filtro da média móvel com 3 pontos em vez de 10 pontos.

4.3. RESULTADOS DOS INDICADORES ESTATÍSTICOS PARA OS 2 MODELOS

					Indicadores Estatísticos		
					RMSE	MAPE(%)	
M o d e l o	M1	Filtro Média Móvel	M=10	H o r i z o n t a l	1 MÊS	109,28	39,30
					1 SEMANA	52,00	28,80
					1 DIA	75,50	29,40
					12 HORAS	29,13	22,51
					6 HORAS	36,43	24,98
			M=3		1 MÊS	119,38	36,06
					1 SEMANA	66,19	38,76
					1 DIA	85,88	32,99
					12 HORAS	27,39	19,94
					6 HORAS	31,97	18,60
M o d e l o	M2	Filtro Média Móvel	M=10	H o r i z o n t a l	1 MÊS	109,02	75,48
					1 SEMANA	52,12	43,66
					1 DIA	75,42	29,30
					12 HORAS	30,71	22,73
					6 HORAS	39,92	25,54
			M=3		1 MÊS	125,58	35,98
					1 SEMANA	66,06	36,68
					1 DIA	88,24	37,21
					12 HORAS	31,13	27,62
					6 HORAS	29,75	17,20

Figura 4.20: Resultados dos Indicadores Estatísticos para os 2 modelos de previsão para vários horizontes temporais.

Na figura 4.21 é possível verificar que a produção é maior quando o vento atinge velocidades mais altas, para velocidades baixas a produção é quase inexistente.




Figura 4.21: Produção em função da velocidade do vento.

4.4 Interface com o utilizador

Por último os resultados obtidos para os modelos desenvolvidos são apresentados de forma gráfica na aplicação desenvolvida. Nas figuras 4.22 e 4.23 é detalhado o processo de visualização dos resultados através da aplicação.

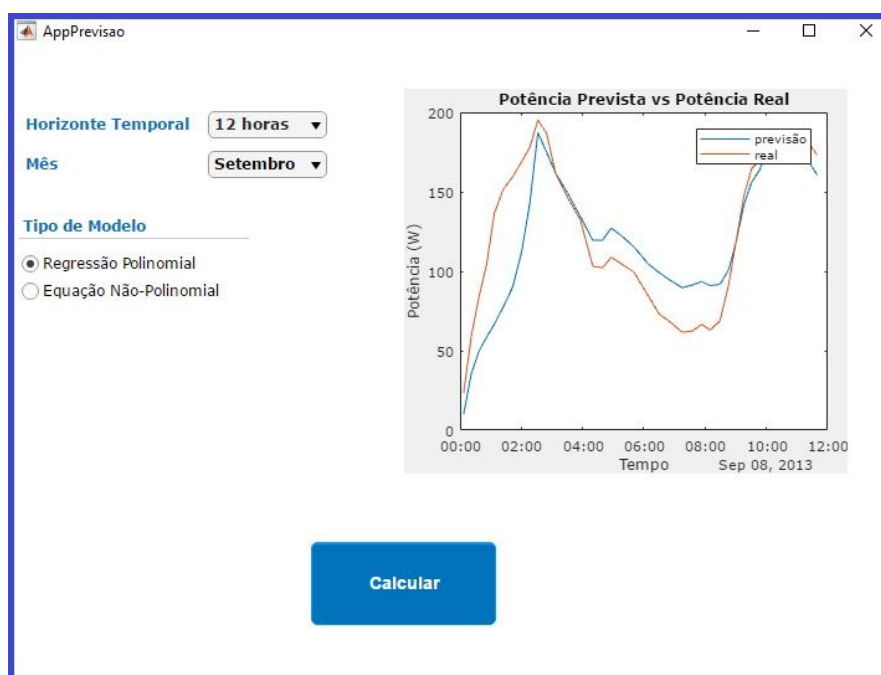


Figura 4.22: Resultados obtidos para as 12h do mês de Setembro para o M1.



Figura 4.23: Resultados obtidos para as 12h do mês de Setembro para o M2.

Os resultados apresentados na aplicação são iguais aos representados nas secções 4.1 e 4.2, sendo que a aplicação apenas facilita ao utilizador o acesso aos resultados das predições sem necessidade de entender o *script* desenvolvido.

CONCLUSÕES E TRABALHO FUTURO

5.1 Conclusões

Para se conseguir prever a produção de energia produzida pelo gerador eólico que se encontra instalado no topo do Departamento de Engenharia Eletrotécnica e de Computadores desenvolveram-se 2 modelos de previsão de potência que seguem uma abordagem estatística. Os 2 modelos desenvolvidos são baseados em estimativa por regressão polinomial e estimativa por equações não polinomiais. Estes 2 modelos foram testados para vários horizontes temporais para averiguar a sua aplicabilidade no local em estudo.

Começou por se fazer uma análise teórica dos modelos de previsão existentes. A escolha recaiu sobre os modelos estatísticos devido à sua simplicidade de implementação e aos requisitos necessários (dados históricos recolhidos no local). De seguida procedeu-se à análise dos dados meteorológicos recolhidos previamente para se conseguir escolher a variável de entrada do sistema. Optou-se por se considerar apenas a velocidade do vento como variável de entrada.

A próxima fase desta dissertação trata-se de um pré-processamento a aplicar aos dados que inclui 3 etapas distintas: redução do número de amostras, eliminação de outliers e por fim aplicação de filtros para atenuação de ruído. Este pré-processamento foi necessário, uma vez que existiam muitas variações bruscas na variável de entrada do sistema, o que teria efeitos negativos na construção do modelo de previsão. Existiam ainda algumas amostras que não faziam sentido no contexto do conjunto de dados, que se pode dever a falhas ou indisponibilidades no sistema, estas amostras foram também eliminadas para evitar erros no modelo.

Este processamento dos dados foi aplicado na fase de treino do modelo e na fase de validação do mesmo.

Após as etapas iniciais foram desenvolvidos os 2 modelos de previsão para vários horizontes temporais para se conseguir comparar o desempenho de ambos os modelos. Os resultados obtidos foram os seguintes:

- O modelo baseado em equações não-polinomiais com um filtro de média móvel de 3 pontos para um horizonte temporal de 6h foi o que obteve melhores resultados. O erro associado a esta previsão foi de 17,20%.
- O modelo baseado em equações não-polinomiais para um horizonte temporal de 1 mês foi o que obteve piores resultados, erro de cerca de 75%.
- Ambos os modelos têm melhores resultados para horizontes temporais mais curtos (6h e 12h).
- Para horizontes temporais superiores a 1 dia os erros associados são demasiado elevados inviabilizando a previsão de potência.
- Conclui-se ainda que a produção é maior para velocidades do vento elevadas.

Por fim foi criada uma aplicação que permite ao utilizador uma interface amigável e intuitiva de visualizar os resultados da previsão da potência para o horizonte temporal, mês e modelo escolhido. Esta aplicação foi desenvolvida apenas para alguns meses mas pode ser adaptada para conseguir fazer previsões para o ano inteiro.

O trabalho desenvolvido resume-se a um sistema capaz de prever a potência produzida por um gerador eólico recorrendo a 2 modelos distintos, desde que seja fornecido ao sistema dados recolhidos anteriormente, para um horizonte temporal definido pelo utilizador.

5.2 Trabalho Futuro

Para trabalho futuro sugere-se criar um sistema de agregação dos dados provenientes da estação meteorológica instalada no topo do DEEC e dos contadores por forma a garantir dados históricos com qualidade para se conseguir melhores resultados em modelos de previsão, evitando assim lacunas nos dados. Sugere-se também o desenvolvimento de um modelo híbrido que integre por exemplo um modelo numérico para conseguir obter previsões para os dados meteorológicos

e um dos modelos estatísticos desenvolvidos nesta dissertação para se conseguir obter resultados mais promissores. Como alternativa aos filtros abordados nesta dissertação seria útil incluir o estudo do Filtro de Kalman para avaliar os resultados obtidos.

BIBLIOGRAFIA

- [1] A. G. C. R. Vaz. “Photovoltaic Forecasting with Artificial Neural Networks”. Tese de mestrado. Universidade de Lisboa, 2014.
- [2] APREN. *Eletricidade Renovável em Revista*. 2018.
- [3] M. N. M. Rolo. “Previsão de Produção Eólica com Modelização de Incertezas”. Tese de mestrado. FEUP, 2014.
- [4] G. Sideratos e N. Hatziargyriou. “An Advanced Statistical Method for Wind Power Forecasting”. Em: *IEEE Transactions on Power Systems*. Vol. 22. 2007, pp. 258–265.
- [5] J. N. M. S. Sousa. “Previsão de Produção Elétrica em Parques Eólicos”. Tese de mestrado. FEUP, 2007.
- [6] F. T. M. Marques. “Aplicação e comparação de metodologias de modelação à previsão de produção de energia eléctrica em centrais eólicas”. Tese de mestrado. Instituto Superior Técnico, 2011.
- [7] Y. Wang. “A Summary of Wind Power Prediction Methods”. Em: *AIP Conference Proceedings*. Vol. 1971. 2018.
- [8] M. Lei, L. Shiyan, J. Chuanwe, L. Hongling e Z. Yan. “A review on the forecasting of wind speed and generated power”. Em: *Renewable and Sustainable Energy Reviews*. Vol. 13,14. Elsevier, mai. de 2009, pp. 915–920.
- [9] C. Stathopoulos, A. Kaperoni, G. Galanis e G. Kallos. “Wind power prediction based on numerical and statistical models”. Em: *Journal of Wind Engineering and Industrial Aerodynamics* (fev. de 2012).
- [10] A. Joensen, G. Giebel, L. Landberg, H. Madsen e H. Nielsen. “Model output statistics applied to wind power prediction.” Em: *Wind Energy for the Next Millennium, European Wind Energy Conference*. Nice, France, mar. de 1999, pp. 1177–1180.
- [11] S. Haykin. “Neural Network: A comprehensive foundation.” Em: 2ª ed. Prentice Hall, 2004. Cap. 1.

- [12] I. G. Damousis, M. C. Alexiadis, J. B. Theocharis e P. S. Dokopoulos. "A Fuzzy Model for Wind Speed Prediction and Power Generation in Wind Parks Using Spatial Correlation". Em: *IEEE Transactions on Energy Conversion*. Vol. 19. Jun. de 2004.
- [13] M. Landin e R. C. Rowe. "Artificial neural networks technology to model, understand and optimize drug formulations". 2013.
- [14] Y. Wu e J. Hon. "A Literature Review of Wind Forecasting Technology in the World". Em: *Proceedings of the W.-Y. Chang 167 IEEE Conference on Power Tech*. Lausanne, jul. de 2007, pp. 504–509.
- [15] S. Soman, H. Zareipour, O. Malik e P. Mandal. "A Review of Wind Power and Wind Speed Forecasting Methods with Different Time Horizons". Em: *Proceedings of the 2010 North American Power Symposium*. Arlington, set. de 2010, pp. 1–8.
- [16] J. L. Guiñón, E. Ortega, J. Garcia-Antón e V. Pérez-Herranz. "Moving average and savitzky-golay smoothing filters using mathcad." Set. de 2007.
- [17] S. J. Orfanidis. *Introduction To Signal Processing*. Prentice Hall International, 1996.
- [18] J. M. Lima, A. K. Guetter, S. R. Freitas e J. Panetta. "A Meteorological-Statistic Model for Short-Term Wind Power Forecasting". 2017.
- [19] M. Lange, U. Focken e D. Heinnemann. "PREVIENTO-REGIONAL WIND POWER PREDICTION WITH RISK CONTROL". Em: WVEC. Berlim, 2002.
- [20] C. Monteiro, R. Bessa, V. Miranda, A. Botterud, J. Wang e G. Conzelmann. *Wind Power Forecasting: State-of-the-Art 2009*. Nov. de 2009.
- [22] G. Giebel. *The State-Of-The-Art in Short-Term Prediction of Wind Power*. 2003.
- [21] G. Giebel, L. Landberg, T. S. Nielsen e H. Madsen. "The Zephyr-Project The next generation prediction system". Em: GWEC. Paris, 2002.
- [23] J. L. S. Cunha. "Sistema de Monitorização Online". Tese de mestrado. Universidade Nova de Lisboa-FCT, 2013.